Learning signal processing in Persian language

Step 11: Complex Ensemble Empirical Mode Decomposition

ساناز جواهریان

دانش‌آموخته کارشناسی ارشد مهندسی پزشکی

دانشکده مهندسی برق و کامپیوتر دانشگاه تهران

برای حل مشکل تخلیط مود ها و نیز کم کردن اثر نویز از روش EEMD استفاده کردیم،اما سیگنال بازسازی شده از این روش حاوی مقداری نویز در بستر خود میباشد که ناشی از اضافه کرد نویز های متفاوت به سیگنال در مرحله ی شناخت IMFها است.

علاوه بر آن ،مقادیر مختلف نویز سفید گوسی، موجب تولید IMFهای مختلف میشود.

برای حل این مشکل از روشی دیگر استفاده میکنیم تا اثرات نویز اضافه شده را کاهش دهد.

این روش را تحت عنوان CEEMD میشناسند که در زیر به شرح الگوریتم آن میپردازیم:

در اینجا IMF ها با IMF_K نمایش داده میشود.

برای توضیح الگوریتم ما اپراتور $E_j(0)$ را تعریف میکنیم که مود ذاتی j ام محاسبه شده به روش EMD است و فرض میکنیم که w^i نویز سفید و x داده ی اصلی و ε_0 یک ضریب ثابت باشد.

1-ابتدا در هر مرحله به هر نمونه از داده درصدی از نویز گوسی اضافه میشود ،سپس با روش EMD تجزیه انجام میگیرد .

برای I نویز سفید گوسی مختلف ،تابع مد ذاتی اول با روش EMD محاسبه میشود.

پس از آن ،مقدار IMF_1 اول CEEMD از میانگین I مود به دست آمده، حاصل میشود.

$$\overline{IMF_1} = \frac{1}{I}\sum_{i=1}^{I} IMF_1^i$$

2-سپس مقدار r_1 از رابطه ی زیر محاسبه میشود

$$r_1 = x - \overline{IMF_k}$$

3-برای بدست آورد IMF_2 ، I بار تابع مود ذاتی اول $r_1+\varepsilon_1 E_1(w^i)$ را که در آن i=1,2,3,...,I است را محاسبه میکنیم و تابع مود ذاتی دوم را بدست میآوریم.

$$\overline{IMF_2} = \frac{1}{I}\sum_{i=1}^{I} E_1(\, r_1 + \varepsilon_1 E_1(\omega^i))$$

4-برای k = 2,3,4,...,k مقدار باقی مانده k ام را محاسبه میکنیم.

$$r_k = r_{k-1} - \overline{IMF_k}$$

5-برای محاسبه ی IMF_{k+1} ام از مقدار $r_k+\varepsilon_k E_k(w^i)$

(که در آن i=1,2,3,...,I است)تابع مود ذاتی را همانند مراحل اول محاسبه میکنیم:

$$\overline{IMF}_{(k+1)} = \frac{1}{I}\sum_{i=1}^{I} E_1(\, r_k + \varepsilon_k E_k(\omega^i))$$

6-این فرآیند را جایی متوقف میکنیم که باقی مانده تنها دو اکسترموم یا کمتر داشته باشد.

7-مقدار باقی مانده نهایی را از رابطه ی زیر محاسبه میکنیم:

$$R = x - \sum_{1}^{k} \overline{IMF}_k$$

بدیهی است که برای بازیابی سیگنال x از رابطه ی زیر استفاده میشود:

$$x = \sum_{1}^{k} \overline{IMF}_k + R$$

در واقع با استفاده از CEEMD در هر مرحله از تجزیه یکبار نویز را شناسایی کرده و با محاسبه ی میانگین در هر سطح ،اثر آنرا کاهش میدهیم.

محققان از روش CEEMD در حذف نویز تصادفی بهره برده اند.

References

1. Akbari, H., M.T. Sadiq, and A.U. Rehman, Classification of normal and depressed EEG signals based on centered correntropy of rhythms in empirical wavelet transform domain. Health Information Science and Systems, 2021. 9(1): p. 1-15.

2. Akbari, H. and M.T. Sadiq, Classification of Seizure and Seizure Free EEG Signals Based on second-order difference plot of DWT coefficients. 2020.

3. Akbari, H., Classification of Seizure and Seizure Free EEG Signals using Geometrical features derived from Poincaré plot, and binary particle swarm optimization.

4. Akbari, H., S.S. Esmaili, and S.F. Zadeh, Classification of seizure and seizure-free EEG signals based on empirical wavelet transform and phase space reconstruction. arXiv preprint arXiv:1903.09728, 2019.

5. Ghofrani, S. and H. Akbari. Comparing nonlinear features extracted in EEMD for discriminating focal and non-focal EEG signals. in Tenth International Conference on Signal Processing Systems. 2019. International Society for Optics and Photonics.

6. Akbari, H. and M.T. Sadiq, Detection of focal and non-focal EEG signals using non-linear features derived from empirical wavelet transform rhythms. Physical and Engineering Sciences in Medicine: p. 1-15.

7. Akbari, H., S. Saraf Esmaili, and S. Farzollah Zadeh, Detection of Seizure EEG Signals Based on Reconstructed Phase Space of Rhythms in EWT Domain and Genetic Algorithm. Signal Processing and Renewable Energy, 2020. 4(2): p. 23-36.

8. Akbari, H. and S. Ghofrani, Fast and accurate classification f and nf EEG by using sodp and EWT. International Journal of Image, Graphics and Signal Processing (IJIGSP), 2019. 11(11): p. 29-35.

9. Hussain, W., et al., Epileptic seizure detection using 1 D-convolutional long short-term memory neural networks. Applied Acoustics, 2021. 177: p. 107941.

10. Sadiq, M.T., X. Yu, and Z. Yuan, Exploiting dimensionality reduction and neural network techniques for the development of expert brain–computer interfaces. Expert Systems with Applications. 164: p. 114031.

11. Sadiq, M.T., et al., Identification of Motor and Mental Imagery EEG in Two and Multiclass Subject-Dependent Tasks Using Successive Decomposition Index. Sensors, 2020. 20(18): p. 5283.

12. Sadiq, M.T., et al., A Matrix Determinant Feature Extraction Approach for Decoding Motor and Mental Imagery EEG in Subject Specific Tasks. IEEE Transactions on Cognitive and Developmental Systems, 2020.

13. Sadiq, M.T., et al., Motor imagery BCI classification based on novel two-dimensional modelling in empirical wavelet transform. Electronics Letters, 2020.

14. Sadiq, M.T., et al., Motor imagery EEG signals classification based on mode amplitude and frequency components using empirical wavelet transform. IEEE Access, 2019. 7: p. 127678-127692.

15. Sadiq, M.T., et al., Motor Imagery EEG Signals Decoding by Multivariate Empirical Wavelet Transform-Based Framework for Robust Brain–Computer Interfaces. IEEE Access, 2019. 7: p. 171431-171451.

16. Arianpour, Y., S. Ghofrani, and H. Amindavar. Locally nonlinear regression based on kernel for pose-invariant face recognition. in 2012 11th International Conference on Information Science, Signal Processing and their Applications (ISSPA). 2012. IEEE.

17. Sharma, M. and U.R. Acharya, Automated detection of schizophrenia using optimal wavelet-based l1 norm features extracted from single-channel EEG. Cognitive Neurodynamics, 2021: p. 1-14.

18. Sharma, M., et al., An automated diagnosis of depression using three-channel bandwidth-duration localized wavelet filter bank with EEG signals. Cognitive Systems Research, 2018. 52: p. 508-520.

19. Sharma, M., et al., An automatic detection of focal EEG signals using new class of time–frequency localized orthogonal wavelet filter banks. Knowledge-Based Systems, 2017. 118: p. 217-227.

20. Sharma, M., et al., Dual-tree complex wavelet transform-based features for automated alcoholism identification. International Journal of Fuzzy Systems, 2018. 20(4): p. 1297-1308.

21. Sharma, M., R.B. Pachori, and U.R. Acharya, A new approach to characterize epileptic seizures using analytic time-frequency flexible wavelet transform and fractal dimension. Pattern Recognition Letters, 2017. 94: p. 172-179.

22. Sharma, M. and R.B. Pachori, A novel approach to detect epileptic seizures using a combination of tunable-Q wavelet transform and fractal dimension. Journal of Mechanics in Medicine and Biology, 2017. 17(07): p. 1740003.

23. Sharma, M., D. Deb, and U.R. Acharya, A novel three-band orthogonal wavelet filter bank method for an automated identification of alcoholic EEG signals. Applied Intelligence, 2018. 48(5): p. 1368-1378.